

基于紫外极光图像的极光电集流指数模型*

肖 晖^{1,2} 田馨沁¹

1(南京航空航天大学航天学院 南京 210016)

2(南京晓庄学院环境科学学院 南京 211171)

摘 要 极光电集流指数 AE 是描述地磁亚暴强弱的重要指标, 且与极区磁层扰动及极光粒子沉降过程密切相关。因此, 建立更加准确的极光电集流指数模型对空间天气的研究具有重要意义。利用 1997 年 POLAR 卫星紫外极光图像数据探究了紫外极光图像中极光强度 I_{AP} 的空间分布与 AE 指数在不同季节的相关性, 并在此基础上提出了基于紫外极光图像的 AE 指数模型。以网格化方法提取极光强度空间分布特征, 采用广义回归神经网络, 通过相关系数法和方差选择法构建 Cor-GRNN 和 Var-GRNN 两种 AE 指数模型, 并针对冬至月份、夏至月份、分点月份 3 个季节分别进行训练。研究表明, AE 指数与 I_{AP} 具有相似的半年变化趋势, 其相关性在不同季节差异较大。相比于太阳风驱动下的 AE 指数神经网络预测模型, 基于极光图像的 AE 指数模型在 E_{RMS} 和 R^2 标准上均优于其他模型, 其中归一化 E_{RMS} 小于 0.1, 模型对于 AE 指数变化的可解释度提升了 10% 左右。

关键词 紫外极光图像, 极光强度分布, 网格化特征, 广义回归神经网络, 极光电集流指数模型

中图分类号 P352

Modeling of Auroral Electrojet Index with Ultraviolet Aurora Image

XIAO Hui^{1,2} TIAN Xinqin¹

1(College of Astronautics, Nanjing University of Aeronautics and Astronautics, Nanjing 210016)

2(School of Environmental School, Nanjing Xiaozhuang University, Nanjing 211171)

Abstract The auroral electrojet index AE is an important indicator to describe the intensity of geomagnetic substorms, and is closely related to the polar magnetosphere disturbance and the precipitation process of auroral particles. Therefore, it is of great significance to establish an accurate prediction model of the electrojet index for the study of space weather. In this paper, the correlation of the spatial distribution of aurora power I_{AP} and AE index in different seasons are studied by using the ultraviolet aurora image data of Polar satellite in 1997, and on this basis, a prediction model of AE index based on the

* 国家自然科学基金项目 (41471381) 和江苏省自然科学基金项目面上项目 (BK20171410) 共同资助

2022-07-15 收到原稿, 2023-01-09 收到修定稿

E-mail: xiaohui@njxzc.edu.cn

©The Author(s) 2023. This is an open access article under the CC-BY 4.0 License
(<https://creativecommons.org/licenses/by/4.0/>)

ultraviolet aurora image is proposed. The grid method is used to extract the spatial distribution characteristics of the aurora intensity of the ultraviolet aurora image. The generalized regression neural network GRNN is used to construct two AE index models, Cor-GRNN model and Var-GRNN model, by using the correlation coefficient method and variance selection method, and training is conducted for the three seasons. The results show that AE and I_{AP} have a similar semi-annual change trend, and their correlation varies greatly in different seasons. Compared with the AE index neural network prediction model driven by the solar wind, the model based on aurora images is superior to other models in terms of E_{RMS} and R^2 standards. The normalized E_{RMS} is less than 0.1, and the model's interpretability for AE index changes is increased by about 10%.

Key words Ultraviolet aurora image, Aurora intensity distribution, Grid features, Generalized regression neural network, Aurora electric current index model

0 引言

目前, 卫星、空间站、电网、通信、导航以及航空控制系统等容易受到磁暴和亚暴等磁层活动的影响, 因此预测地磁活动成为空间天气研究的重要内容之一。极光电集流 AE (Auroral Electrojet) 指数记录了极区极光带的磁扰动变化情况, 是最能反映亚暴强度的指标。沿极光带均匀分布的 12 个磁力计台站记录了当地磁扰动水平 H 分量的时间变化, 将这些台站数据叠画在一起确定的上包络为东向电集流 AU 指数, 下包络为西向电集流 AL 指数。 AE 指数是两者的差值, 提供了总体电流强度水平的度量^[1]。极光电集流体系的空间结构异常复杂, 时间变化十分剧烈。几十年来, AE 指数被广泛用于参数化空间天气事件, 作为各种模型的输入和空间天气的指示。

已有的极光电集流指数预测模型包括非线性物理模型和神经网络模型。预测 AL 指数的非线性模型由太阳风和行星际磁场 (Interplanetary Magnetic Field, IMF) 参数驱动^[2], 随后又有研究建立了磁层粒子传输模型等物理模型, 并以 vB_s 参数 (太阳风速度 v 和行星际磁场南向分量 B_s) 为输入预测地磁指数^[3]。神经网络被用于重建太阳风磁层耦合系统, 并以此来预测电集流活动^[4,5]。关于 IMF 和太阳风参数所起的作用, Ferreira 等^[6] 使用人工神经网络 (ANN) 从太阳风数据中预测 AE 指数, Cai 等^[7] 利用行星际磁场三分量、太阳风密度、速度 5 个参数作为 NARX 神经网络的原始外部输入。为弥补太阳风数据流的缺口, 更好地预测 AE 指数的时间序列, 负时间 AL 指数、

环电流指数 (Dst) 等也加入到预测模型的输入参数中^[8,9]。Gopinath 等^[10] 选择 Dst 指数、太阳风速度分量 (v_x) 和 IMF 南北分量 (B_z) 作为恒定输入参数, 并着重于选择合适的耦合函数作为输入变量来预测 AE 指数。

极光作为太阳风作用于地磁场的传感器, 同样受到太阳风行星际磁场驱动, 其强度及空间位置反映了极光带粒子沉降的分布特征及极区磁层的变化情况, 同时又与地面磁力计观测和地磁指数密切相关^[11]。近年来, 对于极光现象的观测已由地基转向天基, POLAR, IMAGE, TIMED 和 DMSP 等科学卫星拍摄到的大量紫外极光图像为建立 AE 指数模型提供了又一可靠的数据基础^[12]。值得注意的是, 随着研究对于 AE 指数空间分辨率要求的提高, 极光观测数据提供了极光强度的空间分布信息, 在 AE 指数预测方面将起到不可替代的作用。目前, 已有大量研究证明 AE 指数与极光强度、极光功率之间的强相关性^[13,14]。极光椭圆的大小受太阳风磁层耦合和环电流强度的控制, 其位置、形状、强度等可由经验公式推算得出^[15,16]。此外, 还有学者通过 AE 指数及太阳风行星际磁场参数建立了极光椭圆边界回归模型^[17] 和极光强度分布模型等^[18-20]。随着地面磁力计台站数量和数据处理能力的增加, 地面磁力计数据与极光图像数据的关系成为一个更容易处理的问题。因此, 本文主要探究极光强度的空间分布与地磁 AE 指数的关系, 并在此基础上构建一种基于紫外极光图像的 AE 指数模型。

1 地磁 AE 指数与极光强度时空关系的分析

1.1 数据来源

选用的 1997 年紫外极光图像取自 Space Physics Data Facility (SPDF) 网站^{*}的 POLAR 卫星搭载的紫外相机 UVI。该卫星在一个轨道运行周期内(约 18 h), UVI 有至少 9 h 时间可以对极光椭圆区域进行成像观测。由于 LBHS 波段受氧气 Schumann Rungeband 吸收严重, 因此本文使用 POLAR 卫星的 LBHL 波段(160~180 nm)。若考虑每个单独的帧, 图像的时间分辨率从 37 s 到几分钟不等。对于 LBHL 波段图像, 其时间分辨率约为 3 min。每个图像大小为 200 pixel $\times$ 228 pixel, 空间分辨率约为每像素 0.04°。 AE 指数来源于世界数据中心 WDC^{**}, 采用 1 min 时间分辨率的标准 AE 指数, 12 个台站在极坐标系中沿经度近似均匀分布(见图 1)。然而由于卫星观测轨道、寿命等原因, 极光图像数据并非时时连续, 加之空间环境因素对卫星成像的影响, 可能导致所选数据的实际分辨率更低。因此, 模型训练之前需要对极光图像与 AE 指数进行时序匹配。由于磁层电离层耦合作用是对称的, 以下研究皆以北极地区为例。




图 1 地磁台站在磁坐标系下的位置分布

Fig. 1 Location distribution of geomagnetic stations in the magnetic coordinate system

* <https://spdf.gsfc.nasa.gov/pub/data/>

** <http://wdc.kugi.kyoto-u.ac.jp/>


1.2 AE 指数与极光强度随时间的变化

首先考虑 AE 指数和极光强度(Auroral Power, AP)在时间尺度上的变化情况, 此处定义极光强度符号为 I_{AP} 。极光强度 I_{AP} 即极光光子通量, 可以从紫外成像仪 UVI 获取的 LBHL 波段(160~180 nm)的极光光度推断出更加具有物理意义的极光电子能量通量^[21]。首先将 UVI 成像仪收集得到的光子通量 ϕ ($\text{cm}^{-2} \cdot \text{s}^{-1}$) 转换为表面亮度 Ra (Rayleighs), 有

$$Ra = 4\pi / (\Omega 10^6) \phi \cos \theta. \quad (1)$$

其中, ϕ 为 UVI 图像上以线性色标表示的光子通量值, Ω 为单个像素所对的立体角(4.17×10^{-7} sr), 系数 $\cos \theta$ 用来降低视角的视亮度, 校正偏离最低点的像素, θ 是视角。然后, Germany 等^[22] 的数值模型结果确定了表面亮度与极光电子能量通量之间的比例关系约为 $110Ra = 10^{-7} \text{ J} \cdot \text{cm}^{-2} \cdot \text{s}^{-1}$ 。通过上述方法即可完成极光 UVI 图像到极光电子能量通量的转换。图 2 给出了 1997 年 AE , AU , AL 指数和极光强度 I_{AP} 的日平均变化曲线, 采用 30 天滑窗可抑制指数的逐日变化而不过分压低其年变化趋势。图 2(a) 中极光电集流指数表征的地磁活动有明显的半年变化, 即在两分点季(春分, 秋分)活动强, 在两至点季活动弱, 符合 Cliver 等^[23]、Singh 等^[24] 的研究结果。极光强度由于受到日辉的影响呈现出夏季高而冬季低的年变化趋势。因而, 本文采用与 AE 指数相同的去基线的处理方式, 选择每个月 5 个磁静日的平均极光强度作为基线, 绘制了极光强度的年变化曲线(图 2b)。可以看出, 极光强度 I_{AP} 也存在类似的半年变化。令人惊讶的是, 在更细小的时间尺度上(如图 2 阴影部分), AE 与 I_{AP} 的变化也十分相似且同步。事实上, 影响地磁活动特别是亚暴强度和发生频率的主要因素是太阳风磁场南向分量 B_z 的大小及持续时间长短, 太阳风磁场垂直于流向的分量在地磁偶极轴上投影的大小, 引起地磁活动的改变。在春分和秋分点, 地球偶极轴与黄道面法线夹角最大, 太阳风磁场南向分量最大并与地磁场耦合, 此时地磁活动最为剧烈。

为了考察 AE 指数与极光强度在不同季节的相关性, 按照地磁学中惯用的劳埃德季节分别展开研

图2 1997年 AE , AU , AL , I_{AP} 指数 30 天滑动平均的年变化曲线Fig. 2 Annual change curves of 30 day moving average of AE , AU , AL and I_{AP} indexes in 1997

究。图 3 (a)~(c) 分别给出了冬至月份(11月、12月、1月、2月,用 D 表示),夏至月份(5月、6月、7月、8月,用 J 表示),分点月份(3月、4月、9月、10月,用 E 表示) AE 与 I_{AP} 的散点图及线性相关关系拟合。可以看出, D 月份两者的相关性最好达 0.84; J 月份相关性显著降低,且纵轴的截距大幅增加,即在日照的作用下,UVI 捕获的基础能量明显提高。地磁活动最强的 E 月份相关性则最低,仅有 0.59。图 3(d)~(f) 则是由 1997 年 D 月份、J 月份、E 月份的极光 UVI 数据累积显示在地磁纬度 (MLAT) 和磁地方时 (MLT) 网格中的极光强度分布图。如图 3 所示, D 月份极光总强度最弱,且以夜侧极光为主,极光能量主要分布在纬度 60° — 80° 。J 月份正值北半球夏季,在日照作用下 UVI 捕获的极光能量最强甚至覆盖了整个极盖区域(极光卵环带所包围的内部区域)。值得注意的是,夜侧极光能量受到日光的压制作用,而日侧极光能量则大幅增强。D 月份极光强度分布在日侧和夜侧较为平均,夜侧极光更集中分布在午夜附近且靠近纬度 70° ,而日侧极光更容易出现在更高的纬度。

1.3 AE 指数与极光强度空间分布的关系

为分析不同地磁活动状态下极光强度随经纬度

分布的变化情况,本文将极光图像数据按 AE 指数从小到大划分为 3 个等级。 $AE = 0 \sim 200$ nT 的样本为第一等级,表示微扰情况下的极光强度分布; $AE = 200 \sim 600$ nT 的样本为第二等级,表示一般扰动情况下的极光强度分布; $AE > 600$ nT 的样本为第三等级,表示强烈扰动情况下的极光强度分布。

图 4~6 分别是在一、二、三级磁扰动下,极光强度的空间分布随世界时的变化。可以看出,在极光电集流体系中西向电集流 AL 指数对 AE 指数的贡献可达到 $3/4$,而东向电集流的贡献只有 $1/4$,如图 4~6 中的 (a) 所示。极光总是分布在夜间扇区(以 00:00 MLT 为中心的夜半球极光区域),且极光强度极大值也常常位于 00:00 MLT 附近,如图 4~6 中的 (b) 所示。一级扰动时,极光椭圆的磁经度覆盖范围大约为 22:00—03:00 MLT;二级扰动时,极光椭圆延伸至 20:00—06:00 MLT;三级扰动时,极光椭圆继续向两侧延伸甚至覆盖整个夜半球。随着磁扰动的增强,极光会向着赤道方向移动,如图 4~6 中的 (c) 所示,图中的纵坐标表示磁余纬度。一级扰动时,极光椭圆强度极大值出现在磁余纬 18° 左右,宽度约为 10° ;二级扰动时,极光椭圆纬度覆盖范围增加,横跨约 15° ;三级扰动时,极光椭圆向赤道向移动,其覆盖




图3 1997年D(上)、J(中)、E(下)月份极光强度与AE指数的相关性以及极光强度的累积分布。(a)~(c)为AE与 I_{AP} 的散点图和线性关系拟合,(d)~(f)为极光强度的累积分布(色标表示极光强度,取值 $0 \sim 20 \times 10^4 \text{ cm}^{-2} \cdot \text{s}^{-1}$)

Fig. 3 Correlation between the total auroral intensity and AE index in D, J and E months in 1997 and the cumulative distribution of auroral intensity. In (a) ~ (c) Scatter plot and linear relationship fitting of AE and I_{AP} . In (d) ~ (f) cumulative distribution of auroral intensity (The color bar represents the aurora power, with values ranging from 0 to $20 \times 10^4 \text{ cm}^{-2} \cdot \text{s}^{-1}$)

的最低纬度超过了磁余纬 30° ,同时强度极大值点向低纬度移动至磁余纬 25° 。

需要注意的是,图4~6图示3个等级磁扰动极光强度的色标范围不同,若使用相同范围的色标,极

光椭圆的经纬度分布规律会更加突出。总而言之,随着AE指数的增大,极光强度的经纬度分布呈现规律性的变化^[25-27]。相对地,极光强度在磁坐标系下的空间分布特征也可以作为预测AE指数的输入参数。




图 4 一级磁扰动期间 AE , AU , AL 随 UT 的变化曲线 (a), 极光强度磁经度分布的变化 (b), 极光强度经纬度分布的变化 (c)

Fig. 4 During first-order disturbance: (a) variation curves of AE , AU , and AL with UT; (b) variation of magnetic longitude distribution of auroral intensity; (c) variation of latitudinal longitude distribution of auroral intensity




图 5 二级磁扰动期间 AE , AU , AL 随 UT 的变化曲线 (a), 极光强度磁经度分布的变化 (b), 极光强度经纬度分布的变化 (c)

Fig. 5 During second-order disturbance: (a) variation curves of AE , AU , and AL with UT; (b) variation of magnetic longitude distribution of auroral intensity; (c) variation of latitudinal longitude distribution of auroral intensity

2 基于极光图像的地磁 AE 指数模型构建

2.1 紫外极光图像网格化特征提取

为更好地描述 UVI 图像中的极光强度分布特

征, 本文采用了网格化特征提取方法。在特征提取之前, 首先对图像进行预处理、降噪、清洗, 并将其转换到 MLT-MLAT 坐标系下, 再以地磁极点为中心, 以地磁经纬度为切割线, 对图像进行 $1 \text{ MLT} \times 1 \text{ MLAT}$ 的网格化特征提取(见图 7)。通过该方法,




图 6 三级磁扰动期间 AE , AU , AL 随 UT 的变化曲线 (a), 极光强度磁经度分布的变化 (b), 极光强度经纬度分布的变化 (c)

Fig. 6 During third-order disturbance: (a) variation curves of AE , AU , and AL with UT; (b) variation of magnetic longitude distribution of auroral intensity; (c) variation of latitudinal longitude distribution of auroral intensity




图 7 紫外极光图像网格化特征提取过程

Fig. 7 Grid feature extraction process of ultraviolet aurora image

磁经度范围 00:00–24:00 MLT, 纬度范围 50–90 MLAT 的图像可以用 24×40 的极光强度网格化特征 (Gridding Feature of the Auroral Power) 矩阵 G_{AP} 表示, 有

$$G_{AP} = \begin{bmatrix} P_{1,1} & P_{1,2} & \cdots & P_{1,j} & \cdots & P_{1,40} \\ P_{2,1} & P_{2,2} & \cdots & P_{2,j} & \cdots & P_{2,40} \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ P_{i,1} & P_{i,2} & \cdots & P_{i,j} & \cdots & P_{i,40} \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ P_{24,1} & P_{24,2} & \cdots & P_{24,j} & \cdots & P_{24,40} \end{bmatrix}. \quad (2)$$

其中, $i = 1, 2, \dots, 24$; $j = 1, 2, \dots, 40$; $P_{i,j}$ 表示磁地方时在 $[i-1, i]$ 范围内; 磁纬度在 $[90-(j-1), 90-j]$ 范围内的极光强度均值。将极光图像表示为一个特征矩阵, 以便于后续进行特征整合和筛选, 进入神经网络的输入层。

2.2 基于广义回归神经网络的 AE 指数模型

广义回归神经网络 (Generalized Regression Neural Network, GRNN) 具有很快的收敛速度及很强的非线性映射能力, 其网络结构如图 8 所示。从紫外极光图像中提取到网格化特征矩阵后, 并不能直接




图 8 GRNN 网络结构

Fig. 8 GRNN network structure


输入到网络中进行回归预测。原因在于 G_{AP} 特征矩阵的每一个值对应极光图像的一个网格, 而图像的部分网格不包含极光强度信息或仅包含了极少的强度信息, 不利于网络的学习; 作为自变量的特征矩阵存在严重的共线性问题, 使得网络的预测结果相对于测量误差会变得非常敏感。因此, 需要选择有意义的特征对模型进行训练, 通常从两个方面考虑。其一是特征是否发散, 如果一个特征不发散, 例如方差接近于 0, 也就是说样本在这个特征上基本没有差异, 那么这个特征对于样本的区分并没有什么作用; 其二是特征与目标参数的相关性, 显然与目标相关性高的特征, 应当被优先选择。本文分别从方差和相关性两个方面对极光网格化特征进行筛选。方差选择法步骤相同, 相关系数法的具体步骤如下。

步骤 1 计算训练集样本中 24×40 个网格特征与目标 AE 指数之间的相关系数。

步骤 2 对各特征的相关系数进行排序, 保留前 k 个特征, 并对测试集样本进行相同的操作。

步骤 3 将选择后的特征输入神经网络中进行训练并预测 AE 指数。


广义回归神经网络 (GRNN) 是典型的径向基神经网络^[28], 相比其他网络拥有更强的逼近能力和非线性映射能力。通过非参数估计的方法计算输入和输出的概率密度函数, 进而得到网络的最大概率输出。GRNN 在结构上与 RBF 网络较为相似, 由 4 层组成, 分别为输入层 (I), 模式层 (P), 求和层 (S) 和输出层 (O) (见图 8)。图 9 为 AE 指数预测模型流程图。其中, 基于相关系数法特征选择的模型记为 Cor-GRNN, 基于方差选择法特征选择的模型记为 Var-GRNN。

图 9 AE 指数预测模型流程Fig. 9 AE index prediction model flow chart

3 实验结果与评价

由于极光强度与 AE 指数呈现相似的半年变化特征且不同月份极光强度的分布特征明显不同, 因此针对 D, J, E 这 3 个季节分别构建 GRNN 网络预测模型。经预处理后, 共收集到 D 月份图像 46152 张, J 月份图像 45504 张, E 月份图像 36519 张 (其中 3 月数据有大量缺失)。所有图像数据均按照时间顺序排列并匹配同时序 AE 指数形成标签, 训练集与测试集的比例为 4:1, 采用 4 折交叉验证的方式, 将训练集数据 4 等分进行模型选择和调试确定模型超参数, 最终在测试集上进行测试。4 折交叉验证即将训练集数据平均分为 4 份, 将每个子集数据分别做一次验证集, 其余的 3 组子集数据作为训练集, 依次记录模型在每个验证集中的评估结果, 对误差进行平均, 得到交叉验证误差。如图 10 分别给出了 D, J, E 这三组数据集中极光强度的 960 个网格化特征与 AE 指数的相关系数以及其各自的方差。相同的是, 无论是特征的发散程度, 还是特征与目标参数的相关性, 夜侧极光尤其是午夜区域极光强度都值得被优先考虑, 这一特点更充分地显示在 D 月份数据中。不同的是, 尽管 J 月份日侧极光得到增强, 但相比其他月份极光强度与 AE 指数的相关性不增反减。就特征的发散程度而言, J 月份的日侧与夜侧极光发散程度相当, E 月份高发散的网格特征则更集中在夜侧午夜扇区。

引入模型评价标准包括均方根误差 (Root Mean Square Error, RMSE, 定义符号 E_{RMS}), 平均相对方差 (Average Relative Variance, ARV, 定义符号 V_{AR}) 和决定系数 (Coefficient of Determination) R^2 。 R^2 的值越接近 1, 说明回归直线对观测值的拟合程度越好,

图 10 D, J, E 这三组数据集中极光强度网格化特征与 AE 指数的相关系数Fig. 10 Correlation coefficient between grid characteristics of auroral intensity and AE index

模型对于 AE 指数变化的可解释度越高。若以 Y_i 表示实际序列, y_i 表示预测序列, 则可定义

$$E_{\text{RMS}} = \sqrt{\frac{\sum_{i=0}^{n-1} (Y_i - y_i)^2}{n}}, \quad (3)$$

$$V_{\text{AR}} = \frac{\sum_{i=0}^{n-1} (Y_i - y_i)^2}{\sum_{i=0}^{n-1} \left(\frac{\sum_{i=0}^{n-1} Y_i}{n} - Y_i \right)^2}, \quad (4)$$

$$R^2 = 1 - \left| \frac{\sum_{i=0}^{n-1} (x_i - y_i)^2}{\sum_{i=0}^{n-1} Y_i} \right|. \quad (5)$$

经过模型的训练验证和测试后, 表 1 给出了两种模型分别在 D, J, E 三组测试集上的预测性能比较, 图 11 是 D 月份 Cor-GRNN 和 Var-GRNN 两个模型 AE 指数预测结果与真实值的曲线对比图。经分析不难发现, D 月份 AE 指数预测值与真实值之间的 E_{RMS} 和 V_{AR} 都较小, 且模型的 R^2 值超过了 0.95, 表明基于极光强度分布的 GRNN 模型对于 AE 指数变化的可解释程度达到 95%。D 月份正值北半球冬季, 极光受日照影响较小且此时地磁活动性也处于一年中的较低水平, 因而预测效果最优。相比之下, E 月

表 1 两种预测模型在 D, J, E 测试集上的预测性能比较
Table 1 Comparison of prediction performance of two prediction models on D, J, E test sets

Dataset	Model	E_{RMS} (Normalized)	V_{AR}	R^2
D	Cor-GRNN	0.0805	0.2524	0.9555
	Var-GRNN	0.0831	0.2685	0.9526
J	Cor-GRNN	0.0989	0.3164	0.9296
	Var-GRNN	0.0918	0.3282	0.9420
E	Cor-GRNN	0.1019	0.2879	0.9463
	Var-GRNN	0.1096	0.3331	0.9378

注 加粗字体表示两种模型中更好的性能数据。

份由于强烈的地磁扰动给模型预测造成了不小的挑战, 预测结果的 E_{RMS} 大于 0.1, R^2 值也有所下降, 但模型的可解释度仍高于 90%。J 月份的预测模型性能则居于两者之间, 日光的强烈干扰致使其 E_{RMS} 大于 D 月份, 而相对较弱的地磁活动则令它的 E_{RMS} 小于 E 月份。对比 Cor-GRNN 和 Var-GRNN 模型在各个数据集上的表现发现, 前者在 D, E 月份占优, 而后者在 J 月份的预测性能更好。根据前文所述, J 月份夜侧极光能量受到日照的压制作用, 日侧极光能量得到增强。而日光反而削弱了日侧极光强度与 AE 指




图 11 D 月份两种模型 AE 指数预测结果与真实值曲线

Fig. 11 Curve between AE index prediction and reference of two models in D months

表 2 D 月份亚暴发生期间 AE 指数预测模型性能
Table 2 Performance of AE index prediction model during substorm occurrence in D months

Model	E_{RMS} / nT	$E_{RMS}(\text{Normalized})$	V_{AR}	R^2
Cor-GRNN	106.6857	0.1034	0.4799	0.9179
Var-GRNN	119.1728	0.1123	0.5666	0.9032

表 3 本文模型与其他 AE 指数预测模型性能对比
Table 3 Performance comparison between this model and other AE index prediction models

Model	$E_{RMS}(\text{Normalized})$	V_{AR}	R^2
Cor-GRNN	0.0937	0.2850	0.9438
Var-GRNN	0.0948	0.3104	0.9441
ELM	0.1079	0.2854	0.8351
Random forest	0.1246	0.3808	0.7800
FFBP	0.1105	0.2992	0.8271
SVM	0.1307	0.4184	0.7583

注 加粗数据表示性能最优。

数的相关性,从而被相关系数法忽略。

本文还就模型对亚暴发生时 AE 指数的变化进行了预测,以亚暴发生前的图像数据为输入,预测亚暴发生时 AE 指数的变化趋势,其中亚暴事件参照 Newell and Gjerloev 于 2011 年发布的亚暴事件列表^[29,30]。表 2 给出的是两个模型对于 D 月份多次亚暴发生时 AE 指数预测结果的平均值。从结果可以清晰看出,两个模型对于亚暴期间 AE 指数预测的 E_{RMS} 约为 110 nT,归一化的 E_{RMS} 分别是 0.1034 和 0.1123。总体而言,模型对于亚暴膨胀相的预测有不错的表现,并且 Cor-GRNN 模型性能优于 Var-GRNN 模型。然而,相比上述总体预测性能而言,模型对亚暴发生期间 AE 指数的预测准确度明显降低,这是因为亚暴期间的磁扰动比较剧烈,导致 AE 指数变化幅度较大。

表 3 给出了本文的基于极光强度分布的 GRNN 模型与前人基于太阳风驱动的网络模型的预测结果对比。其中,基于太阳风驱动的网络模型的输入参数包括环电流 Dst 指数、极盖 PC 指数、太阳风速分量 v_x 、行星际磁场南北分量 B_z ,神经网络包括极限学习机 ELM、随机森林、前馈反向传播网络 FFBP、支持向量机 SVM。对比结果显示,本文的预测模型获得了最小的 E_{RMS} ,最低的 V_{AR} 以及最高的 R^2 。值得一提的是,本文的模型在拟合优度方面高出太阳风驱动模型至少 10%。

极光电集流指数包含两个主要分量:一个由太阳风驱动,另一个由磁尾卸载过程驱动^[31]。与太阳风直接能量输入相关的极光电集流主要在黄昏和黎明区域流动,并随着对流的增强而增加。而在增长阶段储存在尾部的能量卸载将在亚暴膨胀阶段形成密集的西向电集流,集中在午夜区域。以太阳风参数、行星际磁场分量等为输入的神经网络模型可以很好地预测太阳风直接驱动的 AE 分量,而忽略了磁尾卸载分量,因而这类模型对于 AE 指数的变化解释度远低于本文的模型。

4 结论

利用 1997 年 POLAR 卫星紫外极光图像数据和地面磁力计台站所得的极光电集流指数,首先分析了 AE 指数和极光强度 I_{AP} 的年变化规律,并分别考察了 AE 指数与极光强度的经纬度分布在不同季节的相关性,以及不同等级地磁活动下极光强度分布的变化情况。其次,根据以上分析提出了基于紫外极光图像的 AE 指数模型。采用网格化方法提取紫外极光图像的极光强度空间分布特征,通过相关系数法和方差选择法构建 Cor-GRNN 和 Var-GRNN 两种 AE 指数模型,并针对 D、J、E 这 3 个季节分别进行训练。研究表明, AE 与 I_{AP} 具有相似的半年变化趋势,其相关性在不同季节差异较大, D 月份两者的相关性最好达 0.84, J 月份受日光影响相关性降低 0.15, 地磁活动最强的 E 月份的相关性最低仅有 0.59。换句话说,日光和强烈的地磁活动都会影响 AE 与 I_{AP} 的相关性。北半球冬季极光总强度最弱,且以夜侧极光为主,主要分布在纬度 70° 左右,而夏季的夜侧极光能量受到日光的压制作用,日侧极光能量大幅增强甚至超过了夜侧。D、J、E 这 3 个季节的模型训练和测试结果显示, D 月份的模型预测结果与真实值之间的归一化 E_{RMS} 最小,模型的拟合优度最高。且相比于太阳风驱动下的 AE 指数神经网络预测模型,基于极光图像的预测模型在 E_{RMS} 和 R^2 标准上均优于其他模型。其中,归一化 E_{RMS} 小于 0.1, 模型对于 AE 指数变化的可解释程度提升了 10% 左右。

参考文献

- [1] DAVIS T N, SUGIURA M. Auroral electrojet activity index AE and its universal time variations[J]. *Journal of Geophysical Research*, 1966, **71**(3): 785-801
- [2] BARGATZE L F, BAKER D N, MCPHERRON R L, et al. Magnetospheric impulse response for many levels of geomagnetic activity[J]. *Journal of Geophysical Research: Space Physics*, 1985, **90**(A7): 6387-6394
- [3] KLIMAS A J, VASSILIADIS D, BAKER D N. Data-derived analogues of the magnetospheric dynamics[J]. *Journal of Geophysical Research: Space Physics*, 1997, **102**(A12): 26993-27009
- [4] WEIGEL R S, HORTON W, TAJIMA T, et al. Forecasting auroral electrojet activity from solar wind input with neural networks[J]. *Geophysical Research Letters*, 1999, **26**(10): 1353-1356
- [5] ZHENG Zhichao, ZHANG Kedeng, WAN Xin, et al. Prediction of equatorial electrojet based on the neural network during quiet time[J]. *Chinese Journal of Space Science*, 2021, **41**(3): 392-401 (郑志超, 张科灯, 万欣, 等. 基于神经网络的磁平静期赤道电集流预测[J]. *空间科学学报*, 2021, **41**(3): 392-401)
- [6] FERREIRA A A, BORGES R A. Performance analysis of distinct feed-forward neural networks structures on the AE index prediction[C]// *IEEE Aerospace Conference*. Big Sky: IEEE, 2021: 1-7. DOI: 10.1109/AERO50100.2021.9438504
- [7] CAI L, MA S Y, ZHOU Y L. Prediction of SYM-H index during large storms by NARX neural network from IMF and solar wind data[J]. *Annales Geophysicae*, 2010, **28**(2): 381-393
- [8] AMARIUTEI O A, GANUSHKINA N Y. On the prediction of the auroral westward electrojet index[J]. *Annales Geophysicae*, 2012, **30**(5): 841-847
- [9] ZOU Ziming, CAO Jinbin, LI Yi. Influence of solar wind disturbance on ring current and auroral electrojet indexes[J]. *Chinese Journal of Space Science*, 2012, **32**(1): 14-19 (邹自明, 曹晋滨, 李毅. 太阳风扰动对极光电急流和环电流指数的影响[J]. *空间科学学报*, 2012, **32**(1): 14-19)
- [10] GOPINATH S, PRINCE P R. A comparison of machine-learning techniques for the prediction of the auroral electrojet index[J]. *Journal of Earth System Science*, 2019, **128**(7): 172
- [11] MANSOUR P, BALASIS G, CONSOLINI G, et al. Causality and information transfer between the solar wind and the magnetosphere-ionosphere system[J]. *Entropy*, 2021, **23**(4): 390
- [12] NEWELL P T, LIOU K, SOTIRELIS T, et al. Polar ultraviolet imager observations of global auroral power as a function of polar cap size and magnetotail stretching[J]. *Journal of Geophysical Research: Space Physics*, 2001, **106**(A4): 5895-5905
- [13] LIOU K, CARBARY J F, NEWELL P T, et al. Correlation of auroral power with the polar cap index[J]. *Journal of Geophysical Research: Space Physics*, 2003, **108**(A3): 1108

- [14] CHEN A Q, LI J W, YANG G L, *et al.* Calculating auroral oval pattern by AE index[J]. *Acta Meteorologica Sinica*, 2008, **22**(1): 91-96
- [15] MILAN S E. Both solar wind-magnetosphere coupling and ring current intensity control of the size of the auroral oval[J]. *Geophysical Research Letters*, 2009, **36**(18): L18101
- [16] YANG Qiuju, HU Zejun, HAN Desheng, *et al.* Modeling and prediction of ultraviolet auroral oval boundaries based on IMF/solar wind and geomagnetic parameters[J]. *Chinese Journal of Geophysics*, 2016, **59**(2): 426-439 (杨秋菊, 胡泽骏, 韩德胜, 等. 基于行星际/太阳风和地磁条件的紫外极光卵边界建模和预测[J]. *地球物理学报*, 2016, **59**(2): 426-439)
- [17] HAN Y Y, HAN B, HU Z J, *et al.* Prediction and variation of the auroral oval boundary based on a deep learning model and space physical parameters[J]. *Nonlinear Processes in Geophysics*, 2020, **27**(1): 11-22
- [18] HAN Bing, LIAN Huifang, HU Zejun. Modeling of ultraviolet auroral oval boundaries based on neural network technology[J]. *SCIENTIA SINICA Technologica*, 2019, **49**(5): 531-542 (韩冰, 连慧芳, 胡泽骏. 基于神经网络模型的紫外极光卵边界建模[J]. *中国科学: 技术科学*, 2019, **49**(5): 531-542)
- [19] HU Zejun, HAN Bing, LIAN Huifang. Modeling of ultraviolet auroral intensity based on Generalized Regression Neural Network associated with IMF/solar wind and geomagnetic parameters[J]. *Chinese Journal of Geophysics*, 2020, **63**(5): 1738-1750 (胡泽骏, 韩冰, 连慧芳. 基于广义回归神经网络的行星际/太阳风参数和地磁指数的紫外极光强度建模[J]. *地球物理学报*, 2020, **63**(5): 1738-1750)
- [20] HU Z J, HAN B, ZHANG Y S, *et al.* Modeling of ultraviolet aurora intensity associated with interplanetary and geomagnetic parameters based on neural networks[J]. *Space Weather*, 2021, **19**(11): e2021SW002751
- [21] NEWELL P T, LIOU K, SOTIRELIS T, *et al.* Auroral precipitation power during substorms: a Polar UV Imager-based superposed epoch analysis[J]. *Journal of Geophysical Research: Space Physics*, 2001, **106**(A12): 28885-28896
- [22] GERMANY G A, TOOR M R, TOOR D G, *et al.* Use of FUV auroral emissions as diagnostic indicators[J]. *Journal of Geophysical Research*, 1994, **99**(A1): 383-388
- [23] CLIVER E W, KAMIDE Y, LING A G. Mountains versus valleys: semiannual variation of geomagnetic activity[J]. *Journal of Geophysical Research: Space Physics*, 2000, **105**(A2): 2413-2424
- [24] SINGH A K, RAWAT R, PATHAN B M. On the UT and seasonal variations of the standard and SuperMAG auroral electrojet indices[J]. *Journal of Geophysical Research: Space Physics*, 2013, **118**(8): 5059-5067
- [25] WAN Bingdong, LI Min, WANG Yuan, *et al.* A preliminary analysis of the center latitude distribution of auroral electrojet[J]. *Progress in Geophysics*, 2013, **28**(4): 1655-1661 (万秉东, 李敏, 王源, 等. 极光电集流纬度变化特征初步分析[J]. *地球物理学进展*, 2013, **28**(4): 1655-1661)
- [26] WANG Qiuju, DU Aimin, ZHAO Xudong, *et al.* Manifestation of the AE index in substorms on August 6, 1998[J]. *Chinese Journal of Geophysics*, 2009, **52**(12): 2943-2950 (王秋军, 杜爱民, 赵旭东, 等. 1998年8月6日亚暴期间极光电集流指数AE的特征分析[J]. *地球物理学报*, 2009, **52**(12): 2943-2950)
- [27] XU Wenyao. Variations of the auroral electrojet belt during substorms[J]. *Chinese Journal of Geophysics*, 2009, **52**(3): 607-615 (徐文耀. 亚暴期间极光电集流带的变化[J]. *地球物理学报*, 2009, **52**(3): 607-615)
- [28] SPECHT D F. A general regression neural network[J]. *IEEE Transactions on Neural Networks*, 1991, **2**(6): 568-576
- [29] NEWELL P T, GJERLOEV J W. Evaluation of SuperMAG auroral electrojet indices as indicators of substorms and auroral power[J]. *Journal of Geophysical Research: Space Physics*, 2011, **116**(A12): A12211
- [30] NEWELL P T, GJERLOEV J W. Substorm and magnetosphere characteristic scales inferred from the SuperMAG auroral electrojet indices[J]. *Journal of Geophysical Research: Space Physics*, 2011, **116**(A12): A12232
- [31] PALLOCCIA G, AMATA E, CONSOLINI G, *et al.* AE index forecast at different time scales through an ANN algorithm based on L1 IMF and plasma measurements[J]. *Journal of Atmospheric and Solar-Terrestrial Physics*, 2008, **70**(2/3/4): 663-668